

А. В. Кравцевич, магистрант;
Д. В. Шиман, доц., канд. техн. наук
(БГТУ, г. Минск)

ПРИМЕНЕНИЕ ГЕНЕТИЧЕСКИХ АЛГОРИТМОВ ДЛЯ ТОПОЛОГИЧЕСКОЙ ОПТИМИЗАЦИИ НЕЙРОННЫХ СЕТЕЙ

Искусственная нейронная сеть - математическая модель, а также ее программное воплощение, работающее на основе принципов биологических нейронных сетей. Искусственные нейронные сети во многом повторяют строение биологических.

Нейронные сети являются одним из наиболее популярных на данный момент алгоритмов для аппроксимации различных функций. Но использование нейронных сетей вызывает следующие проблемы:

- выбор оптимальной с точки зрения вычислительной сложности и точности архитектуры;
- схождение сети в локальном минимуме при обучении.

Генетические алгоритмы, как и нейронные сети, вдохновлены происходящими в природе явлениями. Являясь эвристическими алгоритмами оптимизации, генетические алгоритмы используют комбинирование и изменение исходных параметров, используя механизмы, схожие с механизмами естественного отбора.

Задача, решаемая генетическим алгоритмом, должна быть формализована таким образом, чтобы ее потенциальное решение могло быть закодировано с помощью вектора, также называемого геномом, где каждый ген может быть битом, числом или другим объектом (например, в задаче оптимизации функции отдельными генами могут быть коэффициенты данной функции).

В начале работы алгоритма некоторым, обычно случайным образом, создается популяция - набор геномов. Результативность каждого генома оценивается с помощью фитнес-функции - функции, показывающей, насколько хорошо решение, описанное конкретным геномом, решает задачу.

После оценки для дальнейшего использования отбираются геномы, показавшие наилучший результат. Далее отобранные геномы используются для создания потомства с помощью кроссинговера - процесса обмена генами между геномами. Для обогащения получившегося набора геномов различными вариациями используются мутации, случайно изменяющие некоторые из генов (либо полностью, либо на какой-то процент, если это возможно). В дальнейшем получен-

ная популяция проходит те же шаги снова. Критерием завершения работы генетического алгоритма может быть нахождение оптимального решения, либо превышение порогового количества эпох или времени.

В отличие от алгоритма градиентного спуска, генетические алгоритмы позволяют находить глобальный минимум\максимум функции, так как поиск оптимального решения ведется сразу из множества точек в пространстве возможных решений.

Алгоритм, объединяющий нейронные сети и генетические алгоритмы, позволяют производить поиск сети в пространстве возможных весов и топологий, что позволяет находить наиболее оптимальную сеть для определенной задачи [1].

Тем не менее, нейроэволюционные алгоритмы (например, широко распространенный NEAT) обладают одним большим недостатком - они требуют очень больших вычислительных мощностей и времени для работы [2].

Большое количество живых организмов демонстрирует сложное поведение сразу после рождения - обнаружение хищников, плавание, ходьба, еда. Это показывает, что их биологические нейронные сети способны решать задачи, не требуя обучения - а значит, решение подобных задач может быть заложено в структуре нейронной сети, а не только в весах.

По аналогии с подобным поведением биологических сетей, для оптимизации оптимизации нейроэволюционного алгоритма предлагается использовать поиск топологий нейронных сетей, способных работать при любых значениях весов.

Реализация поиска подобных нейронных сетей позволит избавиться от обучения сетей как такового, что непременно приведет к повышению производительности нейросетевого алгоритма.

Стандартный алгоритм нейроэволюции стремится к поиску наиболее производительной нейронной сети, что непременно приводит к крайне быстрому переусложнению топологии в случае игнорирования весов. Поэтому стандартный генетический алгоритм, оптимизирующий только функцию производительности, был заменен на модифицированную реализацию генетического алгоритма многообъектной оптимизации (NSGA-2), который позволяет искать топологию, одновременно стремясь максимизировать производительность сети и минимизировать ее сложность (количество узлов и связей) [3].

Для оценки производительности отдельной топологии используются следующие шаги:

1. Создается несколько копий топологии;
2. Все веса каждой топологии устанавливаются равными числу из диапазона $[-2, 2]$;
3. Получившиеся сети тестируются на задаче;
4. Результаты работы сетей усредняются и считаются общим результатом работы топологии.

В дальнейшем наиболее производительные топологии собираются вместе, используются для создания потомков, хранящих признаки родителей, а также мутируются для расширения диапазона поиска. Данный цикл повторяется до тех пор, пока не будет найдена топология, удовлетворяющая условиям задачи.

Итогом работы описанного алгоритма является нейронная сеть, одинаково хорошо показывающая себя на схожих задачах. Значения весов могут быть подогнаны под каждую конкретную задачу с помощью метода обратного распространения ошибки на уже найденной оптимальной топологии, что позволяет значительно уменьшить время, требуемое для поиска оптимальной сети.

ЛИТЕРАТУРА

1. Representation and evolution of neural networks / Mandischer, M. // Artificial Neural Nets and Genetic Algorithms – 1993. – P. 643 – 649.
2. Evolving neural networks through augmenting topologies / Stanley, K.O. and Miikkulainen, R. // MIT Press. – 2002. – P. 99 – 127.
3. A fast and elitist multiobjective genetic algorithm: NSGA-II / Deb, K., Pratap, A., Agarwal, S. and Meyarivan, T. // IEEE transactions on evolutionary computation, Vol 6(2) – 2002. – P. 182 – 197.